

# Perbandingan Algoritma LSTM Untuk Analisis Sentimen Pengguna Twitter Terhadap Layanan Rumah Sakit Saat Pandemi Covid-19

Anggreiny Rolangon<sup>1</sup>, Axcel Weku<sup>2</sup>, Green Arther Sandag<sup>\*3</sup>

<sup>1,2,3</sup>Fakultas Ilmu Komputer, Universitas Klabat

Jl. Arnold Mononutu, Airmadidi - Minahasa Utara, Sulawesi Utara

e-mail: <sup>1</sup>s21810015@student.unklab.ac.id, <sup>2</sup>s11810008@student.unklab.ac.id,

<sup>\*3</sup>greensandag@unklab.ac.id

## Abstrak

Analisis sentimen telah menjadi aspek penting dalam memahami pendapat dan emosi masyarakat tentang berbagai isu. Dalam penelitian ini, dilakukan analisis sentimen pada *tweet* terkait layanan rumah sakit selama pandemi COVID-19 menggunakan model LSTM, BiLSTM, GRU, dan SimpleRNN. Proses pengumpulan data dilakukan menggunakan Twitter API dan menghasilkan 15.093 *tweet*. Proses *preprocessing* data meliputi pembersihan data, *case folding*, tokenisasi, *filtering*, dan *stemming*. *Dataset* dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Hasilnya menunjukkan bahwa model BiLSTM memiliki akurasi tertinggi sebesar 86%, diikuti model GRU dengan akurasi 86%, model LSTM dengan akurasi 85%, dan model SimpleRNN dengan akurasi 75%. Model BiLSTM juga memiliki MCC tertinggi sebesar 71%. Penelitian ini menyimpulkan bahwa model BiLSTM lebih unggul dibandingkan model lain dalam memprediksi sentimen *tweet* terkait layanan rumah sakit selama pandemi COVID-19. Temuan penelitian ini dapat memiliki implikasi signifikan bagi penyedia layanan kesehatan dalam meningkatkan kualitas layanan dan meningkatkan kepuasan pasien selama pandemi.

**Kata Kunci:** Twitter, LSTM, GRU, BiLSTM, SimpleRNN

## ***The Comparison of LSTM Algorithms for Twitter User Sentiment Analysis on Hospital Services During the Covid-19 Pandemic***

### ***Abstract***

*Sentiment analysis has become a crucial aspect in understanding people's opinions and emotions on various issues. In this study, we conducted sentiment analysis on tweets related to hospital services during the COVID-19 pandemic using LSTM, BiLSTM, GRU, and SimpleRNN models. The data collection process was carried out using the Twitter API and resulted in 15,093 tweets. The data preprocessing process includes data cleaning, case folding, tokenization, filtering, and stemming. The dataset was divided into 80% for training and 20% for testing. The results showed that the BiLSTM model had the highest accuracy of 86%, followed by the GRU model with an accuracy of 86%, the LSTM model with an accuracy of 85%, and the SimpleRNN model with an accuracy of 75%. The BiLSTM model also had the highest MCC of 71%. The study concludes that the BiLSTM model outperformed other models in predicting the sentiment of tweets related to hospital services during the COVID-19 pandemic. This study's findings may have significant implications for healthcare providers in enhancing their services' quality and improving patients' satisfaction during pandemics.*

**Keywords:** Twitter, LSTM, GRU, BiLSTM, SimpleRNN

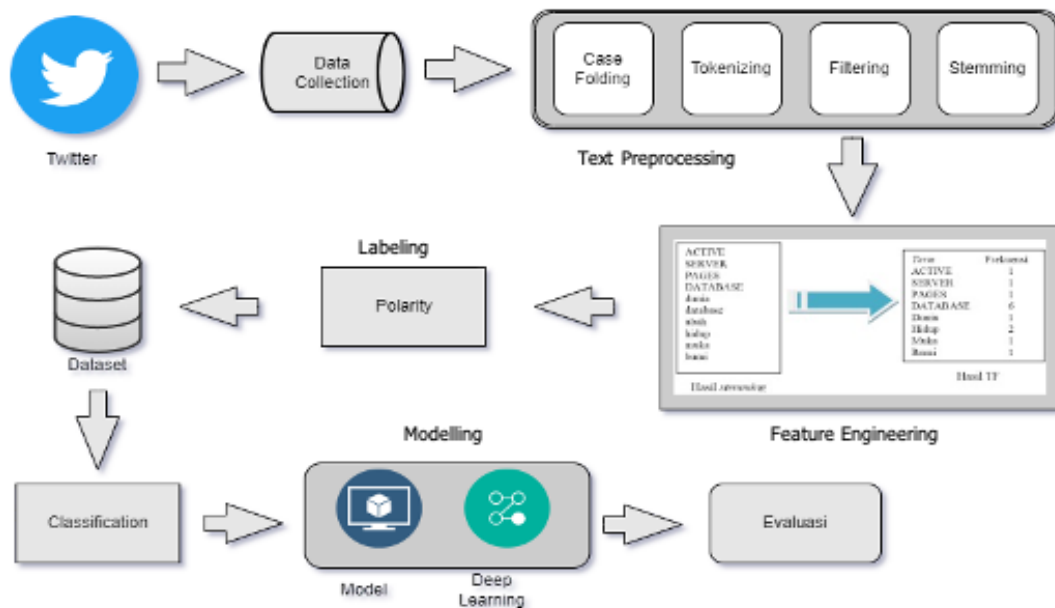
## 1. Pendahuluan

Pandemi Covid-19 telah menjadi pandemi global yang berdampak pada banyak aspek kehidupan, termasuk kesehatan. Di masa pandemi, pelayanan kesehatan memegang peranan yang sangat penting dalam menghadapi pandemi ini, termasuk pelayanan rumah sakit. Kualitas pelayanan rumah sakit di masa pandemi menjadi tujuan utama mengingat ketersediaan tenaga medis, peralatan medis dan kapasitas rumah sakit yang semakin terbatas [1]. Oleh karena itu, penting untuk menilai keadaan layanan rumah sakit selama pandemi dan meningkatkan kualitasnya jika perlu. Banyak kritik dan keluhan terhadap pelayanan rumah sakit selama pandemi COVID-19, seperti kurangnya perawatan pasien dan kekurangan peralatan medis [2][3]. Keluhan tersebut dapat ditemukan melalui media sosial, khususnya Twitter, di mana pengguna dapat berbagi pengalaman dan pendapatnya tentang layanan rumah sakit selama pandemi COVID-19. Analisis sentimen merupakan metode pengolahan data yang dapat digunakan untuk menganalisis pendapat pengguna Twitter tentang layanan rumah sakit selama pandemi COVID-19. Metode ini memungkinkan pengumpulan data dalam jumlah besar dalam waktu singkat dan dapat membantu peneliti memahami opini publik tentang layanan rumah sakit selama pandemi COVID-19. Menganalisis sentimen dapat menilai kualitas pelayanan rumah sakit di masa pandemi. Twitter adalah platform media sosial yang memungkinkan pengguna untuk berbagi informasi dan pendapat tentang topik tertentu, termasuk pengalaman mereka menerima layanan medis dari rumah sakit selama pandemi. Analisis sentimen dapat membantu menentukan opini publik tentang pelayanan rumah sakit selama pandemi dan apakah opini tersebut positif, negatif, atau netral [4]. Salah satu metode yang dapat digunakan untuk melakukan analisis sentimen adalah *Long Short Term Memory (LSTM)*. LSTM adalah jenis arsitektur jaringan saraf tiruan yang dapat mempelajari dan memproses data secara berurutan. LSTM cocok untuk menganalisis data berurutan seperti teks dan dapat mengenali pola dalam data untuk membuat prediksi tentang sentimen [5]. Dalam konteks ini, LSTM dapat digunakan untuk memeringkat sentimen *tweet* terkait layanan rumah sakit selama pandemi. Metode LSTM dipilih dalam penelitian ini karena dapat memodelkan dan mempelajari hubungan jangka panjang antar data, seperti dalam teks yang mengandung kalimat yang membutuhkan konteks untuk pemahaman yang tepat. LSTM dapat mengatasi kendala tersebut dengan mengingat konteks sebelumnya pada setiap tahapan pengolahan data. Oleh karena itu, metode ini sangat cocok untuk digunakan dalam analisis sentimen pada data Twitter yang cenderung memiliki teks yang kaya dan kompleks. Beberapa penelitian sebelumnya telah menggunakan analisis sentimen pada data Twitter untuk menilai kualitas layanan kesehatan, termasuk rumah sakit. Misalnya, studi oleh Agrawal [6] melakukan analisis sentimen terhadap *tweet subdomain* Kesehatan: vaksin covid-19, faktor Kesehatan, dan penyedia layanan kesehatan selama pandemi Covid-19. Hasil kajian menunjukkan bahwa mayoritas *tweet* terkait pelayanan rumah sakit di masa pandemi bernada positif. Selain itu, studi oleh Sandag [7] juga melakukan analisis sentimen terhadap *tweet* terkait vaksin covid 19 di Indonesia dan menemukan bahwa mayoritas *tweet* bernada negative dan metode LSTM memberikan 91% Akurasi. Namun penelitian ini berfokus pada analisis terhadap vaksin COVID-19 secara umum selama pandemi, tanpa berfokus pada persepsi terkait pelayanan rumah sakit. Oleh karena itu, penelitian ini akan fokus menganalisis sentimen terhadap pelayanan rumah sakit selama pandemi di Twitter dengan menggunakan metode LSTM. Penelitian yang serupa oleh Saptari [4] juga melakukan analisis sentimen terhadap pelayanan unit gawat darurat rumah sakit umum di Indonesia menggunakan seleksi fitur dan SVM dengan AUC sebesar 0.993, pada penelitian ini hanya menggunakan metode SVM sebagai metode pembuatan model begitu juga dengan penelitian dari Aruan [8] melakukan analisis sentimen opini masyarakat terhadap pelayanan rumah sakit umum daerah menggunakan SVM dengan hasil Akurasi sebesar 87.5%. Berdasarkan penelitian sebelumnya maka kami memilih menggunakan metode LSTM untuk membangun model untuk analisis sentimen terhadap pelayanan rumah sakit dan membandingkan metode LSTM dengan metode yang serupa seperti, SimpleRNN, BiLSTM, dan GRU. Penelitian ini akan fokus pada analisis sentimen terhadap pelayanan rumah sakit selama pandemi COVID-19 di Twitter dengan menggunakan metode LSTM. Objek penelitian dalam penelitian ini adalah *tweet* yang terkait dengan layanan rumah sakit selama pandemi COVID-19 di Twitter. Peneliti tidak membatasi *tweet* hanya dari satu rumah sakit saja karena penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap layanan rumah sakit secara umum selama pandemi Covid-19,

bukan hanya pada satu rumah sakit atau wilayah tertentu. Dengan memperoleh data *tweet* dari berbagai rumah sakit di berbagai lokasi, peneliti dapat memperoleh gambaran yang lebih komprehensif dan representatif tentang sentimen masyarakat terhadap pelayanan rumah sakit selama pandemi Covid-19 di Indonesia. Metode LSTM dipilih karena dapat memodelkan dan mempelajari hubungan jangka panjang antar data, seperti dalam teks yang mengandung kalimat yang membutuhkan konteks untuk pemahaman yang tepat. LSTM dapat mengatasi kendala tersebut dengan mengingat konteks sebelumnya pada setiap tahapan pengolahan data. Oleh karena itu, metode ini sangat cocok untuk digunakan dalam analisis sentimen pada data Twitter yang cenderung memiliki teks yang kaya dan kompleks. Ada beberapa batasan pada penelitian ini. Pertama, *dataset* yang digunakan dalam penelitian ini hanya mencakup *tweet* yang menggunakan bahasa Indonesia, sehingga hasil dari penelitian ini mungkin tidak dapat digeneralisasi pada *tweet* yang ditulis dalam bahasa lain. Kedua, penelitian ini hanya fokus pada sentimen *tweet* terkait pelayanan rumah sakit selama pandemi Covid-19, sehingga tidak memperhitungkan faktor lain yang mungkin mempengaruhi sentimen pengguna layanan kesehatan, seperti biaya dan aksesibilitas. Ketiga, meskipun peneliti telah menggunakan beberapa jenis arsitektur LSTM yang berbeda, penelitian ini tidak mempertimbangkan teknik *deep learning* lainnya yang dapat meningkatkan kinerja pengklasifikasi sentimen, seperti metode *transfer learning*.

## 2. Metode Penelitian

Metode penelitian sentimen analisis Twitter terhadap pelayanan rumah sakit saat pandemik Covid menggunakan LSTM (*Long Short-Term Memory*) adalah metode penelitian kuantitatif yang menggunakan teknik analisis data berbasis *machine learning*. Penelitian ini bertujuan untuk menganalisis sentimen pengguna Twitter terhadap layanan kesehatan di rumah sakit pada masa pandemik Covid, dan untuk memprediksi sentimen pengguna di masa depan. Berikut desain dan Langkah-langkah penelitian.



Gambar 1 Desain Penelitian

Langkah pertama pada desain penelitian seperti pada Gambar 1 adalah mengumpulkan data dari Twitter dengan menggunakan API Twitter. Untuk mengumpulkan data dari Twitter dengan API, perlu menentukan parameter pencarian, seperti kata kunci, waktu, lokasi, atau bahasa. Setelah parameter pencarian ditentukan, kemudian mengirimkan permintaan API dan mendapatkan data dalam format JSON. Setelah data terkumpul, kemudian melakukan *data preprocessing* dan mempersiapkannya untuk analisis lebih lanjut. *Data preprocessing* terhadap *tweet* tentang pelayanan rumah sakit dapat dilakukan dengan menggunakan beberapa teknik seperti *data cleaning*, *casefolding*, *tokenizing*, *filtering*, dan *stemming*.

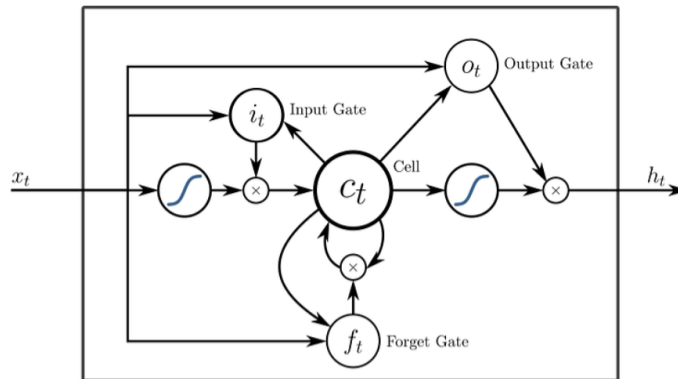
Tahapan pertama yaitu pembersihan data atau *data cleaning* dilakukan untuk menghapus karakter-karakter yang tidak diperlukan pada *tweet*, seperti tanda baca, angka, dan karakter khusus lainnya. Hal ini dilakukan agar data lebih bersih dan mudah diolah. Selain itu, pembersihan data juga dapat mempercepat proses pengolahan data. Kemudian dilakukan *casefolding* untuk mengubah semua huruf dalam *tweet* menjadi huruf kecil. Tujuan *casefolding* adalah untuk menghindari duplikasi data selama analisis data. Ini karena dua kata yang sama tetapi huruf kapitalnya berbeda dianggap dua kata yang berbeda. Setelah itu, dilakukan *tokenizing* untuk membagi *tweet* sebagai istilah-istilah terpisah. *Tokenizing* adalah proses pengubahan teks menjadi *token-token* (unit-unit kecil) yang memiliki arti dan dapat diproses lebih lanjut. *Tokenizing* dilakukan dengan memecah teks menjadi kata-kata, frasa, atau simbol-simbol penting lainnya, yang kemudian dijadikan *token*. Teknik *tokenizing* bertujuan untuk memudahkan pemrosesan data dan memperoleh informasi yang lebih spesifik dari data teks. Selanjutnya, dilakukan *filtering* untuk menghilangkan kata-kata yang tidak relevan atau kata-kata *stopword* dari *tweet*. Kata-kata *stopword* adalah kata-kata umum yang tidak memiliki makna yang signifikan pada *tweet*, seperti "dan", "yang", "pada", "ke", dan sebagainya. Hal ini dilakukan agar data yang dihasilkan lebih fokus pada kata-kata yang penting dan mengurangi *noise* pada data. Terakhir, dilakukan *stemming* untuk mengubah kata-kata dalam *tweet* menjadi bentuk dasarnya. *Stemming* dilakukan untuk mengurangi variasi kata yang sama pada *tweet* sehingga dapat memudahkan dalam analisis data. Contohnya, kata-kata seperti "berlari", "berlalu", dan "berlalu-lalang" akan diubah menjadi kata dasar "lalu" sehingga pada saat analisis data, kata-kata tersebut akan dihitung sebagai satu kata. Secara umum, *data preprocessing* pada *tweet* tentang pelayanan rumah sakit dilakukan dengan tujuan untuk menghilangkan *noise* pada data dan memudahkan dalam analisis data. Dalam penelitian ini, *data preprocessing* pada *tweet* dilakukan sebelum dilakukan sentimen analisis menggunakan metode LSTM. Kemudian dilakukan penentuan *polarity*, selanjutnya membangun model dengan metode LSTM dan terakhir dilakukan evaluasi model dengan menggunakan *confusion matrix*. Penelitian ini menggunakan beberapa tools dalam tahapan preprocessing hingga evaluasi analisis sentimen. Dalam tahapan *preprocessing*, peneliti menggunakan *library* NLTK untuk melakukan *case folding*, *tokenisasi*, dan menghapus *stopword* pada data *tweet*. Selain itu, peneliti juga menggunakan *library* Sastrawi untuk melakukan *stemming/lematisasi* pada data *tweet*. Setelah tahap *preprocessing* selesai, peneliti melakukan analisis sentimen menggunakan metode *rule-based*. Proses analisis sentimen dilakukan dengan menggunakan bahasa pemrograman Python pada Google Colaboratory.

### **SimpleRNN (Recurrent Neural Network)**

SimpleRNN (*Recurrent Neural Network*) adalah sebuah jenis jaringan saraf buatan yang digunakan untuk memproses urutan data dengan mempertahankan memori dari urutan sebelumnya. Konsep SimpleRNN didasarkan pada model neuron yang saling terhubung, sehingga setiap neuron pada layer tertentu akan menerima masukan dari seluruh neuron pada layer sebelumnya. Proses ini memungkinkan SimpleRNN untuk mengingat informasi dari waktu sebelumnya dan menghasilkan *output* yang sesuai [9].

### **Long Short-Term Memory (LSTM)**

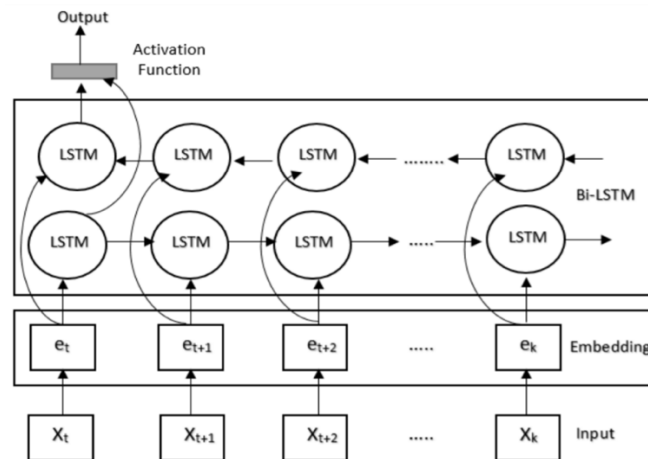
*Long Short-Term Memory* (LSTM) merupakan salah satu jenis arsitektur jaringan saraf tiruan yang digunakan untuk memproses *data sequential* atau *time series* dengan tujuan mengatasi masalah *vanishing gradien* dan *exploding gradien*. LSTM dikembangkan oleh Hochreiter dkk yang memiliki kemampuan untuk mengingat dan melupakan informasi dalam jangka waktu yang lebih lama dibandingkan dengan arsitektur jaringan saraf tiruan lainnya seperti RNN [10]. Oleh karena itu, LSTM menjadi salah satu pilihan populer dalam bidang pemrosesan bahasa alami, pengenalan suara, dan lainnya. LSTM pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 [11]. Arsitektur LSTM terdiri dari tiga gerbang yaitu *input gate*, *forget gate*, dan *output gate*, serta satu sel memori (*memory cell*). *Input gate* digunakan untuk mengontrol seberapa banyak informasi baru yang akan dimasukkan ke dalam sel memori. *Forget gate* digunakan untuk menghapus informasi yang tidak lagi relevan dari sel memori. *Output gate* digunakan untuk mengontrol seberapa banyak informasi yang akan dikeluarkan dari sel memori [12].



**Gambar 2** Arsitektur Long Short-term Memory (LSTM)

### ***Bidirectional Long Short-Term Memory (BiLSTM)***[7]


*Bidirectional Long Short-Term Memory (BiLSTM)* adalah jenis *neural network* yang menggunakan arsitektur LSTM pada kedua arah *input*, yaitu maju dan mundur, untuk menghasilkan *output*. Pendekatan ini memungkinkan model untuk mempelajari konteks baik dari masa lalu maupun masa depan dari *input*, yang berguna dalam banyak tugas pemrosesan bahasa alami (NLP), seperti pemrosesan teks dan analisis sentimen. BiLSTM menggunakan dua unit LSTM yang terhubung secara terbalik: satu LSTM yang memproses *input* secara maju, dan satu LSTM lagi yang memproses *input* secara mundur[13]. Dalam proses pelatihan, BiLSTM belajar untuk memprediksi *output* berdasarkan konteks yang terdapat pada kedua arah *input*. Model ini mampu menangkap informasi kontekstual pada level yang lebih tinggi dan memiliki kemampuan untuk menangani masalah kesulitan jangka panjang (*long-term dependencies*) pada data yang kompleks[5].



**Gambar 3** Arsitektur BiLSTM

### **GRU (*Gated Recurrent Unit*)**

GRU (*Gated Recurrent Unit*) adalah salah satu tipe arsitektur model jaringan saraf tiruan rekuren (RNN) yang dikembangkan oleh Cho et al. pada tahun 2014 [14][15]. GRU digunakan untuk mengatasi masalah yang dihadapi oleh model RNN tradisional, yaitu masalah *vanishing gradien* dan *exploding gradien* saat melakukan *backpropagation*. GRU memiliki struktur yang mirip dengan LSTM, tetapi lebih simpel dan efisien karena hanya menggunakan dua *gate* yaitu *update gate* dan *reset gate*. *Update gate* digunakan untuk mengontrol seberapa banyak informasi baru yang akan disimpan dalam memori sel[16]. Sementara *reset gate* digunakan untuk mengontrol seberapa banyak informasi lama yang akan disimpan dalam memori sel[17].



Gambar 4 Arsitektur *Gated Recurrent Units*

### Confusion Matrix

*Confusion matrix* merupakan metode yang digunakan untuk mengukur performa dari model klasifikasi dengan membandingkan nilai aktual dengan nilai prediksi. *Confusion matrix* berisi empat nilai yaitu *true positive (TP)*, *true negative (TN)*, *false positive (FP)*, dan *false negative (FN)*. TP merupakan jumlah data yang benar diklasifikasikan sebagai positif, TN merupakan jumlah data yang benar diklasifikasikan sebagai negatif, FP merupakan jumlah data yang salah diklasifikasikan sebagai positif, dan FN merupakan jumlah data yang salah diklasifikasikan sebagai negatif. *Confusion matrix* umumnya digunakan pada analisis sentimen untuk mengukur seberapa baik model dapat mengklasifikasikan sentimen suatu teks [7]. *Accuracy* adalah metode yang digunakan untuk mengukur persentase kesesuaian antara nilai aktual dengan nilai prediksi dari suatu model klasifikasi. Nilai akurasi dapat dihitung dengan rumus 1:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

*Precision* adalah metode yang digunakan untuk mengukur seberapa akurat model dalam mengklasifikasikan suatu data sebagai positif. Nilai *precision* dapat dihitung dengan rumus 2:

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

*Precision* umumnya digunakan pada kasus di mana salah klasifikasi ke kelas positif memiliki dampak yang signifikan, misalnya pada kasus deteksi spam email. *Recall* atau juga disebut *sensitivity* atau *true positive rate*, adalah metode yang digunakan untuk mengukur seberapa baik model dapat mengklasifikasikan data positif secara keseluruhan. Nilai *recall* dapat dihitung dengan rumus 3:

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

*Recall* umumnya digunakan pada kasus di mana salah klasifikasi ke kelas negatif memiliki dampak yang signifikan, misalnya pada kasus deteksi penyakit. MCC (*Matthews Correlation Coefficient*) adalah metode yang mengukur korelasi antara nilai aktual dan nilai prediksi dalam bentuk matriks. Nilai MCC berada di antara -1 hingga 1, di mana nilai -1 menunjukkan korelasi yang sempurna tetapi negatif, 0 menunjukkan ketidakkorelasi, dan 1 menunjukkan korelasi yang sempurna dan positif. Nilai MCC dapat dihitung dengan rumus:

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (4)$$

MCC digunakan untuk mengukur performa suatu model klasifikasi dalam kasus di mana kelas positif dan negatif memiliki distribusi yang tidak seimbang.

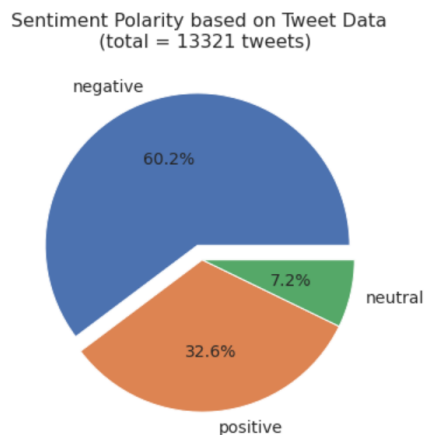
### 3. Hasil dan Pembahasan

Bagian ini berisi hasil dan pembahasan mengenai analisis sentimen pelayanan rumah sakit selama pandemi COVID-19 dengan menggunakan metode LSTM pada data *tweet*. Data yang dikumpulkan menggunakan *keyword* "pelayanan rs", dan "layanan rumah sakit" selama periode 2020-03-31 sampai 2020-12-31 dengan total data *tweet* sebanyak 15093 data. Selanjutnya dilakukan data preprocessing dan diperoleh data sebanyak 13321 data *tweet*.

**Tabel 1** Data preprocessing

No.	username	text_clean	text_preprocessed
1.	RestinaSiagian	covid menggila tempat tidur isolasi ruang icu rs kian penuh tingkat keterisian icu nd isolasi nd	['covid', 'gila', 'tidur', 'isolasi', 'ruang', 'icu', 'rs', 'kian', 'penuh']
2.	bluejoonjin	aku bulan kemaren juga di rawat di rs hari karena covid kak dan alhamdulillah berkat di beri semngat nakes yg disana tiap aku bisa sembuh sekarang semngat kakkk	['kemaren', 'rawat', 'rs', 'covid', 'kak', 'alhamdulillah', 'berkat', 'semngat', 'nakes', 'yg', 'sana', 'sembuh', 'semngat', 'kakkk']
3.	antgunawan	teman saya rumah di puri kartika cileduk positif covid butuh perawatan lanjut krn kesulitan bernafas tetapi sulit sekali dapat rsu yg bisa tangani karena penuh semua kemana lagi harus meminta bantuan ini sekarang terpaksa masuk ugd rs yg biayanya sangat besar	['teman', 'rumah', 'puri', 'kartika', 'cileduk', 'positif', 'covid', 'butuh', 'awat', 'krn', 'sulit', 'nafas', 'sulit', 'rsu', 'yg', 'tangan', 'penuh', 'mana', 'bantu', 'paksa', 'masuk', 'ugd', 'rs', 'yg', 'biaya']

Setelah semua data *tweet* telah bersih kemudian dilakukan penentuan *polarity*. *Polarity* dalam konteks analisis sentimen adalah pengukuran apakah suatu teks atau kalimat mengandung sentimen positif, negatif, atau netral. Pada penelitian ini, metode yang digunakan untuk menentukan *polarity* dari *tweet* adalah dengan menggunakan pendekatan *rule-based*, yaitu dengan menggunakan daftar kata (*lexicon*) yang telah dikategorikan berdasarkan polaritasnya (positif, negatif, atau netral). *Lexicon* yang digunakan dalam penelitian ini adalah InSet (Indonesia *Sentiment Lexicon*) [18]. Dalam analisis sentimen pada *tweet*, *polarity* dapat dibagi menjadi dua kategori utama, yaitu polaritas positif dan negatif. *Tweet* dengan polaritas positif memiliki sentimen yang cenderung positif, seperti senang, puas, atau terkesan dengan layanan rumah sakit. Sebaliknya, *tweet* dengan polaritas negatif memiliki sentimen yang cenderung negatif, seperti kecewa, marah, atau merasa tidak puas dengan layanan rumah sakit. *Tweet* dengan polaritas netral tidak memiliki sentimen positif atau negatif yang signifikan.



**Gambar 4** Polarity *tweet* pelayanan rumah sakit selama pandemic covid-19


Gambar 4 menunjukkan persentase *polarity tweet* pelayanan rumah sakit selama pandemi covid-19 di mana *polarity negative* masih mendominasi sebesar 60.2% atau sebanyak 8026 *tweet*, kemudian *tweet* dengan *polarity positive* sebesar 32.6% atau sebanyak 4337 *tweet*, dan *polarity neutral* sebesar 7.2% atau

sebanyak 959 *tweet*. Hal ini menunjukkan bahwa mayoritas pengguna Twitter merasa negatif terhadap pelayanan rumah sakit selama pandemi COVID-19. Sebagai contoh, beberapa pengguna Twitter merasa kesulitan dalam mendapatkan perawatan medis yang dibutuhkan atau merasa tidak puas dengan cara rumah sakit menangani kasus COVID-19. Meskipun demikian, terdapat sejumlah *tweet* dengan *polarity positive* yang menunjukkan pengguna Twitter yang merasa puas dengan pelayanan rumah sakit selama pandemi COVID-19. Pada pembuatan model peneliti memilih untuk menggunakan *dataset* dengan *polarity negative* dan positif, sedangkan netral hanya digunakan dalam analisis. Pada Gambar 4 terdapat distribusi data yang tidak seimbang hal ini karena mencerminkan kondisi yang dapat terjadi di dunia nyata, di mana polaritas negatif pada umumnya lebih sering muncul dalam konteks analisis sentimen khususnya pada layanan kesehatan, termasuk pelayanan rumah sakit selama pandemi Covid-19. Selain itu, penggunaan *dataset* tersebut dapat membantu menguji keandalan algoritma dalam mengenali dan mengklasifikasikan sentimen negatif yang lebih kompleks dan beragam dalam konteks layanan kesehatan.

### Analisis Word Cloud

Analisis *word cloud* adalah metode visualisasi yang menampilkan kata-kata yang paling sering muncul dalam suatu teks dengan ukuran yang berbeda-beda, di mana ukuran kata akan semakin besar jika kata tersebut semakin sering muncul dalam teks. Analisis *word cloud* sering digunakan untuk memberikan gambaran umum tentang topik atau tema yang paling banyak dibicarakan dalam suatu teks

**Gambar 4** *Word Cloud* keseluruhan *tweet*, *positive tweet* dan *negative tweet* tentang pelayanan rumah sakit selama pandemic covid-19



Berdasarkan Gambar 4 di atas, kata-kata yang dapat muncul dalam analisis word cloud keseluruhan dapat meliputi "rs", "pasi en covid", word cloud pada kata positif adalah "positif", "sudah" dan "sehat", selanjutnya untuk kata negative adalah "sakit", "kena". Semakin sering kata-kata tersebut muncul dalam kesimpulan, semakin besar ukuran kata dalam analisis *word cloud* tersebut. Berdasarkan hasil *word cloud* di atas masih terdapat beberapa *stopword* yang belum terhapus sehingga masih muncul pada *word cloud* tersebut.

### Analisis Sentimen

Setelah dilakukan analisis *word cloud*, pada tahap selanjutnya adalah membuat model yang akan menganalisa sentimen dari *data tweet* yang diperoleh menggunakan LSTM. Sebelum data tersebut dimasukkan ke model untuk di-*train* data dipisahkan menjadi dua bagian, yaitu *data training* sebanyak 80% dan data testing sebanyak 20%. Total data yang dihasilkan adalah 9890 data untuk *training* dan 2473 data untuk testing. Kemudian, membuat model dan melakukan *training* atau *fitting* terhadap data yang sudah diproses sebelumnya. Pada penelitian ini juga dilakukan perbandingan antara model simpleRNN, LSTM, BiLSTM, dan GRU.



**Tabel 2** Perbandingan SimpleRNN, LSTM, BiLSTM, dan GRU

Algoritma	Accuracy	Recall	Precision	MCC
LSTM	85%	79%	80%	68%
GRU	86%	76%	84%	69%
<b>BiLSTM</b>	<b>86%</b>	<b>84%</b>	<b>79%</b>	<b>71%</b>
SimpleRNN	75%	54%	70%	44%

Berdasarkan Tabel 2 dari keempat model yang ada, jika dilihat dari nilai metrik tersebut, model yang paling baik adalah BiLSTM dengan akurasi sebesar 86%, *recall* sebesar 84%, *precision* sebesar 79%, dan MCC sebesar 71%. Model LSTM juga cukup baik dengan akurasi 85%, *recall* 79%, *precision* 80%, dan MCC 68%. Model GRU juga cukup baik dengan akurasi 86%, *recall* 76%, *precision* 84%, dan MCC 69%. Namun, model SimpleRNN memiliki performa yang lebih rendah dibandingkan dengan ketiga model lainnya dengan akurasi 75%, *recall* 54%, *precision* 70%, dan MCC 44%. Oleh karena itu, model yang paling baik untuk menganalisis sentimen dari data *tweet* pelayanan rumah sakit selama pandemi Covid-19 adalah BiLSTM. Kinerja BiLSTM lebih baik dibanding dengan jenis LSTM lainnya karena BiLSTM memiliki dua layer LSTM yang berjalan maju dan mundur secara simultan, sehingga mampu mengakses konteks dari kedua arah dan mempertimbangkan informasi kontekstual yang lebih luas. Hal ini memungkinkan BiLSTM untuk mengatasi masalah *vanishing gradient* yang sering terjadi pada model LSTM biasa dan juga memperbaiki kemampuan model untuk mempelajari ketergantungan jarak jauh antara kata dalam teks. Dengan kata lain, BiLSTM dapat memperhitungkan hubungan antara kata-kata yang jauh dalam kalimat, sehingga mampu menghasilkan prediksi sentimen yang lebih akurat. Selain itu, karena BiLSTM memiliki lebih banyak parameter dibandingkan jenis LSTM lainnya, hal ini juga dapat membantu meningkatkan akurasi dan performa model secara keseluruhan. Oleh karena itu, BiLSTM memiliki kinerja yang lebih baik dalam analisis sentimen dari data *tweet* pelayanan rumah sakit selama pandemi Covid-19.

#### 4. Kesimpulan

Penelitian yang dilakukan dalam penelitian ini memerlukan pengembangan model yang dapat mengolah topik peneliti mengenai pelayanan rumah sakit selama pandemi COVID-19 dan menganalisis sentiment mengenai topik-topik ini. Dalam penelitian ini, *dataset tweet* yang berbahasa Indonesia yang diambil dengan *keyword* "pelayanan rs" dan "layanan rumah sakit" sebanyak 15.093 *tweets* dan di proses dan diproses menjadi 13.321. Berdasarkan hasil analisis performa model, dapat disimpulkan bahwa model BiLSTM menghasilkan performa terbaik dengan akurasi sebesar 86%, *recall* sebesar 84%, *precision* sebesar 79%, dan MCC sebesar 71%. Sedangkan model LSTM dan GRU memiliki performa yang cukup baik dengan akurasi masing-masing sebesar 85% dan 86%. Namun, model SimpleRNN memiliki performa yang paling rendah dengan akurasi sebesar 75%. Oleh karena itu, dapat disimpulkan bahwa model BiLSTM dapat digunakan sebagai model yang paling baik untuk melakukan analisis sentimen terhadap data *tweet* terkait pelayanan rumah sakit selama pandemi COVID-19.

#### 5. Daftar Pustaka

- [1] H. Leite, C. Lindsay, and M. Kumar, "COVID-19 outbreak: implications on healthcare operations," *TQM J.*, vol. 33, no. 1, pp. 247–256, 2021, doi: 10.1108/TQM-05-2020-0111.
- [2] S. R. Razu *et al.*, "Challenges Faced by Healthcare Professionals During the COVID-19 Pandemic: A Qualitative Inquiry From Bangladesh," *Front. Public Heal.*, vol. 9, no. August, 2021, doi: 10.3389/fpubh.2021.647315.
- [3] AHA, "Data Brief: Health Care Workforce Challenges Threaten Hospitals' Ability to Care for Patients," *Am. Hosp. Assoc.*, no. August, pp. 2020–2021, 2022, [Online]. Available: <https://www.aha.org/system/files/media/file/2021/11/data-brief-health-care-workforce-challenges-threaten-hospitals-ability-to-care-for-patients.pdf>.

- [4] R. Saptari, Rianto, and A. I. Gufroni, "Analisis Sentimen Pengguna Twitter Terhadap Pelayanan Unit Gawat Darurat Rumah Sakit Umum di Indonesia Menggunakan Seleksi Fitur Information Gain dan Support Vector Machine," *Journal Oof Informatics Education*, vol. XX. pp. 104–110, 2018, [Online]. Available: <http://e-journal.ivet.ac.id/index.php/jiptika/article/view/1925/1369>.
- [5] R. C. Staudemeyer and E. R. Morris, "Understanding LSTM -- a tutorial into Long Short-Term Memory Recurrent Neural Networks," pp. 1–42, 2019, [Online]. Available: <http://arxiv.org/abs/1909.09586>.
- [6] S. Agrawal, S. K. Jain, S. Sharma, and A. Khatri, "COVID-19 Public Opinion: A Twitter Healthcare Data Processing Using Machine Learning Methodologies," *Int. J. Environ. Res. Public Health*, vol. 20, no. 1, 2023, doi: 10.3390/ijerph20010432.
- [7] G. A. Sandag, A. M. Manueke, and M. Walean, "Sentiment Analysis of COVID-19 Vaccine *Tweets* in Indonesia Using Recurrent Neural Network (RNN) Approach," *3rd Int. Conf. Cybern. Intell. Syst. ICORIS 2021*, 2021, doi: 10.1109/ICORIS52787.2021.9649648.
- [8] J. D. C. Aruan, B. Rahyudi, and A. Ridok, "Analisis Sentimen Opini Masyarakat terhadap Pelayanan Rumah Sakit Umum Daerah menggunakan Metode Support Vector Machine dan Term Frequency – Inverse Document Frequency," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 5. pp. 2072–2078, 2022.
- [9] A. P. Rodrigues *et al.*, "Real-Time Twitter Spam Detection and Sentiment Analysis using Machine Learning and Deep Learning Techniques," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/5211949.
- [10] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [11] I. Goodfellow, Y. Bengio, and A. Courville, "Book: Deep Learning," *Prmu*, pp. 1–10, 2016, [Online]. Available: [www.deeplearningbook.org](http://www.deeplearningbook.org).
- [12] S. Minaee, E. Azimi, and A. Abdolrashidi, "Deep-Sentiment: Sentiment Analysis Using Ensemble of CNN and Bi-LSTM Models," 2019, [Online]. Available: <http://arxiv.org/abs/1904.04206>.
- [13] M. Rhanoui, M. Mikram, S. Yousfi, and S. Barzali, "A CNN-BiLSTM Model for Document-Level Sentiment Analysis," *Mach. Learn. Knowl. Extr.*, vol. 1, no. 3, pp. 832–847, 2019, doi: 10.3390/make1030048.
- [14] K. Cho *et al.*, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, pp. 1724–1734, 2014, doi: 10.3115/v1/d14-1179.
- [15] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," pp. 1–9, 2014, [Online]. Available: <http://arxiv.org/abs/1412.3555>.
- [16] R. Ni and H. Cao, "Sentiment Analysis based on GloVe and LSTM-GRU," *Chinese Control Conf. CCC*, vol. 2020-July, pp. 7492–7497, 2020, doi: 10.23919/CCC50068.2020.9188578.
- [17] M. B. Silva, *Percepção da população assistida sobre a inserção de estudantes de medicina na Unidade Básica de Saúde*, First Edit., vol. 1, no. 9. O'Reilly Media, 2016.
- [18] F. Koto and G. Y. Rahmaningtyas, "Inset lexicon: Evaluation of a word list for Indonesian sentiment analysis in microblogs," *Proc. 2017 Int. Conf. Asian Lang. Process. IALP 2017*, vol. 2018-Janua, no. December, pp. 391–394, 2018, doi: 10.1109/IALP.2017.8300625.